



Doi: <https://doi.org/10.70577/ASCE/478.502/2025>

Recibido: 2025-05-13

Aceptado: 2025-06-13

Publicado: 2025-07-15

Integración de Tecnologías Digitales y Analítica del Aprendizaje para la Enseñanza Personalizada del Cálculo Diferencial en Educación Superior

Integration of Digital Technologies and Learning Analytics for Personalized Differential Calculus Teaching in Higher Education

Autor:

John Eduardo Guñanzaca Vaca

john.guinzaca@unae.edu.ec

<https://orcid.org/0000-0003-1801-7380>

Universidad Nacional de Educación
Cuenca-Ecuador

Pedro Daniel Armijo Guamán

denielarmijo2021@gmail.com

<https://orcid.org/0009-0008-9531-7647>

Independiente
Guayaquil-Ecuador

Eduardo Agustín Serrano Estrada

eserrano@humane.edu.ec

<https://orcid.org/0009-0002-4300-0601>

**Humane Tecnológico Universitario de
Negocios**
Guayaquil-Ecuador

Toapanta Cunalata Oscar Gabriel

oscartoapantaambjlm@gmail.com

<https://orcid.org/0000-0002-5816-1785>

Instituto Superior Tecnológico Pelileo
Tungurahua-Ecuador

Carlos Fernando Heredia Villamarín

fernando.heredia@educacion.gob.ec

<https://orcid.org/0009-0006-4369-1915>

Ministerio de Educación del Ecuador
Quito - Ecuador

Cómo citar

Guñanzaca Vaca, J. E., Armijo Guamán, P. D., Serrano Estrada, E. A., Toapanta Cunalata, O. G., & Heredia Villamarín, C. F. (2025). Integración de Tecnologías Digitales y Analítica del Aprendizaje para la Enseñanza Personalizada del Cálculo Diferencial en Educación Superior . *ASCE*, 4(3), 478–502.



Resumen

Esta investigación tiene como objetivo estudiar cómo el uso de la tecnología digital, junto con técnicas de análisis de aprendizaje, permite la instrucción personalizada del cálculo diferencial para estudiantes de educación superior. En particular, busca rastrear la interacción, el rendimiento, el progreso académico y determinar el impacto de la retroalimentación automatizada combinada con rutas de aprendizaje adaptativas en el rendimiento y la motivación del estudiante. Para lograr este objetivo, se aplicó un método de investigación mixto, que constó de un componente cuantitativo; recopilación y análisis de datos de plataformas educativas, y un componente cualitativo a través de entrevistas semi-estructuradas y cuestionarios con estudiantes y profesores. La muestra consistió en 180 estudiantes de primer año matriculados en un curso de Cálculo Diferencial en dos universidades públicas, divididos en grupo experimental (con enseñanza de tecnología/análisis) y grupo de control (enseñanza tradicional). El período de estudio fue un semestre académico (16 semanas). Los principales hallazgos revelan que el grupo experimental logró un rendimiento significativamente más alto en las pruebas de Cálculo Diferencial (media del 85 % frente al 74 % en el control; $p < 0.01$). Además, el análisis de las rutas digitales reveló que el sistema estaba adaptando adecuadamente el nivel de desafío después de tres errores consecutivos, lo que redujo la incidencia de estancamiento en los intentos en un 20 %. Las entrevistas indicaron que los estudiantes percibieron un aumento en la motivación, autonomía y confianza, atribuyéndolo a la retroalimentación inmediata y las rutas personalizadas. La facultad notó la reducción en el tiempo dedicado a la calificación de tareas y la capacidad de dirigir las sesiones tutoriales hacia áreas conceptualmente más desafiantes como cambios positivos. La importancia de estos resultados radica en el hecho de que el uso de tecnología digital y análisis de aprendizaje permite una orientación personalizada, fomentando un enfoque centrado en el estudiante incluso en el Cálculo Diferencial, un campo notoriamente abstracto. Se concluye que esta sinergia podría mejorar el aprendizaje significativo y disminuir las tasas de abandono, ayudando así a formar una generación de graduados con sólidas habilidades analíticas. Además, se sugiere que este modelo sea adaptado en otras ramas de las matemáticas y modificado para diferentes contextos educativos.

Palabras clave: Tecnología Educativa, Analítica del Aprendizaje, Personalización del Aprendizaje, Cálculo Diferencial, Educación Superior, Retroalimentación Automatizada, Rutas de Aprendizaje Adaptativas.



Abstract

The research aims to study how digital technology and learning analytics enable personalized instruction in differential calculus for higher education students. It seeks to assess the impact of automated feedback combined with adaptive learning pathways on student achievement and motivation by tracking interaction, performance, and academic progress. A mixed-method research approach was used to achieve the goal. It included quantitative data collection and analysis from educational platforms, as well as qualitative semi-structured interviews and questionnaires with students and faculty. 180 first-year students were divided into an experimental group with technology-enhanced instruction and a control group with traditional teaching. The students were enrolled in a Differential Calculus course at two public universities. The study lasted 16 weeks, one academic semester. The experimental group achieved significantly higher performance in Differential Calculus assessments compared to the control group (average score of 85% vs. 74%; $p < 0.01$). The system effectively adjusted the level of challenge after three consecutive errors, reducing performance stagnation by 20% in digital learning pathways. Students attributed increased motivation, autonomy, and confidence to immediate feedback and personalized learning routes in interviews. Positive outcomes noted by faculty members included reduced grading time and the ability to focus tutorial sessions on challenging concepts. The integration of digital technology and learning analytics enables personalized guidance in Differential Calculus, fostering a student-centered approach. This is significant because Differential Calculus is a notoriously abstract subject. Synergy can enhance learning and reduce dropout rates, developing graduates with strong analytical skills. The model should be adapted to other branches of mathematics and different educational contexts..

Keywords: Educational technology, learning analytics, learning personalization, differential calculus, higher education, automated feedback, adaptive learning paths.



Introducción

Contextualización del Tema

En el ámbito universitario, la enseñanza del cálculo diferencial se topa con un abanico de desafíos originados por su carácter conceptual y la diversidad de formación previa de los estudiantes (Vera-Valdés & Gutiérrez, 2022). En este contexto, la integración de tecnologías digitales —como plataformas educativas digitales y sistemas flexibles— junto con la analítica del aprendizaje (LA) abre puertas inexploradas para una pedagogía a medida (Martínez-Monés et al., 2023). Estas tecnologías facilitan la recopilación de datos de interacción y su análisis para adaptar los caminos educativos a las necesidades individuales de los estudiantes (Romero & Ventura, 2022), lo cual es de particular valor para dominar conceptos complejos como el cálculo integral y diferencial (Romero & Ventura, 2022).

Evaluación histórica Revisión de archivos.

En ciertos estudios, las tecnologías digitales han revolucionado la educación STEM, revelando resultados con una promesa colosal. En Brasil, Costa y sus colegas (2023) idearon un entorno digital flexible que elevó la eficiencia en cálculo diferencial de un 68 % a un 82 %. En el ámbito español, López-García y Pérez-Sánchez (2021) revelaron que integrar videos dinámicos y encuestas en Moodle, junto con el análisis de patrones de error, elevó en un 15 % la exactitud en la resolución de problemas. En tierras mexicanas, Durán-Pineda y sus colegas implementaron análisis de clickstream para descubrir puntos de estancamiento en secuencias de derivación, lo que resultó en una reducción del 20% en el tiempo de solución. Además, Singh y Chandra (2023) en su revisión sistemática afirman que los sistemas adaptativos basados en... Al fundó el enfoque adaptativo para mejorar la retención y satisfacción entre los aprendices en un 25%. En Argentina, Gallo et al. (2022) implementaron en ejercicios de integración la función de recomendación, lo que condujo a un incremento en la tasa de acierto del 76 % al 89 %.

El uso de estrategias activas así como el uso de tecnologías digitales en el aula resulta en la comprensión profunda de conceptos abstractos en matemáticas, un fenómeno ya evidenciado por varios estudios. Acosta Porras et al. (2024) demostraron la asimilación del saber en las ciencias sociales con actividades competencias con el aprendizaje activo, una técnica que también puede ser adaptada al cálculo diferencial a nivel universitario. Igualmente, Alarcón Burneo et al. (2024)

demonstraron que los recursos manipulables potencian de manera significativa la comprensión de conceptos matemáticos abstractos en la educación secundaria, consolidando la noción de que los ambientes de aprendizaje activos promueven la formación cognitiva.

Análogamente, Álvarez Piza et al. (2024) el fomento del pensamiento lógico por medio de la resolución de problemas en la educación básica influyó notablemente sobre la habilidad analítica del alumnado. Sin embargo, el análisis de la innovación en estrategias formativas por Arequipa Molina et al. (2024), quienes examinaron la manera en que la capacitación docente en estrategias innovadoras potencia el aprendizaje matemático, subrayando la necesidad de habilidades técnicas y pedagógicas integradas.

Bernal Párraga et al. (2024) examinaron la implementación de la gamificación en el campo de las matemáticas, evidenciando que potencia la motivación y el compromiso estudiantil, componentes fundamentales para preservar el interés en campos tradicionalmente desafiantes como el cálculo diferencial. Adicionalmente, Guishca Ayala y colaboradores (2024) subrayaron la importancia de la inteligencia artificial para personalizar la instrucción en matemáticas, dado que ajusta los ejercicios a las habilidades y limitaciones individuales, lo que se alinea perfectamente con la propuesta de analítica adaptativa de este estudio.

En contraposición, Castillo Baño y colaboradores (2024) investigaron el papel de las tecnologías digitales en la formación para la ciudadanía, demostrando que su aplicación sistemática fomenta habilidades críticas y autogestivas en los estudiantes, competencias que se pueden aplicar a la solución de problemas complicados en cálculo diferencial. Cosquillo Chida et al. (2025) también enfatizaron que la innovación con las Tecnologías de la Información y la Comunicación (TIC) en el campo matemático potencia el razonamiento lógico a través de estrategias interactivas.

La investigación de Bernal Párraga et al. (2025), centrada en la inteligencia artificial en el aprendizaje del inglés, evidenció que los sistemas adaptativos personalizados promueven el aprendizaje significativo en disciplinas académicas, lo que respalda teóricamente la transferencia de dichas soluciones al ámbito del cálculo diferencial.



Fierro Barrera et al. (2024) identificaron que el refuerzo académico en matemáticas, cuando se acompaña de tecnologías de retroalimentación rápida, mejora enormemente las ganancias de aprendizaje fundamentales. Esto es consistente con los beneficios del sistema BKT utilizado en este estudio. Quiroz Moreira y colegas (2024) enfatizaron que las plataformas de evaluación digital mejoran la retroalimentación y promueven el aprendizaje en relación con importantes contribuciones a la analítica adaptativa.

Lo más notable, Zamora Arana et al. (2024) destacaron las aplicaciones del aprendizaje adaptativo impulsado por IA en la educación primaria, abogando por su uso en la enseñanza a nivel universitario y sugiriendo un camino de desarrollo para la instrucción del cálculo diferencial.

2. Identificación del problema de investigación y formulación del problema de investigación.

Pese a los progresos anteriores, se identifica una disparidad significativa: escasas investigaciones integran de manera sistemática tecnologías adaptativas y lenguaje de programación en cursos convencionales de cálculo diferencial, particularmente en entornos de habla hispana. Además, aspectos como la validez pedagógica, la accesibilidad y la ética en el uso de datos no han recibido un tratamiento exhaustivo (García-Peñalvo et al, 2023; Serrano et al, 2024). Como resultado, esto justifica la necesidad de estudiar el diseño y la evaluación de una plataforma de aprendizaje que integre estos componentes para mejorar el aprendizaje significativo y cerrar las brechas de logro.

3. Fundamentación del análisis académico

La presente investigación se ubica teóricamente dentro del constructivismo cognitivo (Piaget, 1970) y el enfoque sociocultural (Vygotsky, 1978), los cuales fomentan una construcción activa del conocimiento mediada por instrumentos tecnológicos. En esto que respecta a marcos tecnológicos, se fundamenta en el modelo TPACK (Mishra & Koehler, 2006) and en sistemas adaptativos como el Bayesian Knowledge Tracing, los cuales han sido validados para disciplinas STEM (Chen et al., 2023). Además, se fundamenta sobre los principios de las promotores de personalización: perfilado, predicción, retroalimentación y visualización del progreso (Siemens & Long, 2011; Peña-Acuña et al., 2023).



4. Objetivo y metas propuestas.

Objetivo.

Se analizará el impacto que tiene la inclusión de herramientas digitales y de analítica del aprendizaje en la personalización de la enseñanza del cálculo diferencial en la universidad.

Meta general.

Se medirá el efecto de esa estrategia sobre el rendimiento académico, la motivación y el sentido de autonomía de los estudiantes en la materia.

Objetivos específicos.

Diseñar y poner en marcha un entorno adaptativo que utilice algoritmos de aprendizaje automático para guiar el estudio del cálculo diferencial.

Comparar los resultados del grupo experimental que usa el sistema con los del grupo control que recibe enseñanza tradicional.

Inspeccionar el discernimiento de los alumnos y profesores en relación a la personalización pedagógica.

Evaluar la exactitud de los modelos predictivos y la eficacia de la retroalimentación producida.

Metodología y materiales

2.1 Metodología de la investigación y diseño del estudio

Se adoptó un método híbrido explicativo (Cuantitativo → Cualitativo), sin ensayos, y en sintonía con técnicas de aprendizaje de excelencia (Chaparro Amaya et al., 2023). Esta táctica desentraña patrones de conducta digital y, posteriormente, desentraña las raíces a través de un análisis

cualitativo (Ramírez-Echeverry et al., 2023). La elección del diseño se fundamenta en la mezcla armoniosa de datos amplios y profundos (Johnston & Jendoubi, 2024; Roy & Swargiary, 2024).

2.2 Elección y Definición de la Muestra

En 2024, dos universidades públicas acogieron a estudiantes de primer año de cálculo diferencial. La muestra intencional no probabilística fue de 180 participantes (90 grupo experimental, 90 control), siguiendo criterios de representación institucional y diversidad académica, conforme a recomendaciones de diseño de muestra en estudios edu-tech (Chaparro Amaya et al., 2023).

2.3 Tecnologías Emergentes Aplicadas en el Estudio

La utilización de dispositivos de última generación, software especializado

Este minucioso estudio integró una amplia gama de innovaciones tecnológicas de naturaleza adaptativa y analítica, con el propósito de personalizar y adecuar el proceso de enseñanza del cálculo diferencial en entornos académicos universitarios. Las herramientas tecnológicas seleccionadas se fundamentan en principios de adaptabilidad, seguimiento continuo del progreso de los estudiantes y retroalimentación inmediata, en consonancia con las recomendaciones de los expertos Romero y Ventura (2022) y Chatti et al. (2023).

Primero se utilizó la plataforma de aprendizaje Moodle, famosa en el ámbito universitario por su habilidad de rastrear datos en vivo (Cheng et al., 2023). Los archivos de interacción recolectados revelaron métricas esenciales como el tiempo de permanencia, la frecuencia de acceso, el número de intentos por actividad, la calificación obtenida y los patrones de abandono, fundamentales para moldear el comportamiento de aprendizaje (Rodríguez & Meneses, 2024).

En el corazón del análisis, se abrazó el modelo Bayesian Knowledge Tracing (BKT), una técnica probabilística que calcula el conocimiento escondido del alumno a partir de su rendimiento continuo (Sun, 2025). Este esquema fue ajustado siguiendo las directrices de Chen et al. (2023) y ha sido implementado con éxito en ámbitos STEM (Takami et al., 2021).

Complementariamente, se desarrolló un sistema de recomendación explicable basado en inferencias del BKT, el cual ofrecía feedback inmediato y rutas adaptativas a partir de errores



repetidos, contribuyendo a evitar estancamientos cognitivos (García et al., 2023). Este componente se alineó con principios de inteligibilidad algorítmica para maximizar la aceptabilidad pedagógica, como sugieren Stinar et al. (2025).

Se diseñó un dashboard de analítica visual adaptativa basado en el modelo FCL-SRL (Chatti et al., 2023). Esto permite a docentes y estudiantes visualizar indicadores clave de progreso autorregulado. La visualización soportó procesos de toma de decisiones instruccionales en contextos universitarios, según las buenas prácticas de Learning Analytics (Peña-Acuña et al., 2023).

Finalmente, todo el ecosistema tecnológico fue articulado dentro de un marco estructurado TPACK (Mishra & Koehler, 2006), asegurando la coherencia entre contenidos disciplinares, herramientas digitales y prácticas pedagógicas significativas.

2.4 Desarrollo y Ejecución del Procedimiento

El método de investigación fue elaborado en tres etapas interrelacionadas, fundamentadas en el modelo explicativo mixto secuencial, que facilitó la integración del análisis cuantitativo de interacciones digitales con la interpretación cualitativa de percepciones y experiencias, asegurando la triangulación de datos y consolidando la validez del estudio (Chaparro Amaya et al., 2023; Johnston & Jendoubi, 2024).

Fase 1: Implementación de Intervención Cuantitativa (Semanas 1 a 16)

A lo largo de esta etapa, se llevó a cabo la intervención pedagógica en el contexto natural de un aula virtual. El grupo experimental accedió a contenidos del curso de cálculo diferencial a través de un LMS Moodle configurado con rutas personalizadas de aprendizaje. Cada estudiante fue vinculado a un sistema Bayesian Knowledge Tracing (BKT) parametrizado con perfiles iniciales ($p_{init} = 0.25$) y tasas de aprendizaje ajustadas iterativamente (Chen et al., 2023; Sun, 2025).

Las tareas involucraron videos explicativos, ejercicios resueltos, cuestionarios adaptativos y simulaciones interactivas. El sistema de recomendación, fundamentado en los datos del BKT, direccionaba de manera automática al estudiante hacia actividades remediales tras tres errores

consecutivos en un mismo nodo de conocimiento (Takami et al.), 2021. Además, los datos de interacción se extrajeron de los registros del sistema de aprendizaje virtual (LMS) en variables tales como la duración del acceso, la cantidad de intentos, la secuencia de navegación, el rendimiento y la tasa de abandono (Rodríguez & Meneses, 2024).

El grupo de control empleó la misma plataforma, sin embargo, sin la implementación de personalización ni retroalimentación adaptativa, lo que facilitó la formulación de un contraste experimental legítimo.

Fase 2: Recopilación y Evaluación Cualitativa (Semanas 17 y 18).

Al concluir el semestre, se llevaron a cabo entrevistas semiestructuradas ($n = 20$ alumnos seleccionados mediante muestreo teórico) y se establecieron dos grupos focales con profesores del campo de las matemáticas. Las entrevistas abordaron percepciones sobre autonomía, claridad del feedback, fluidez en el uso de la plataforma y percepción de avance cognitivo. Se aplicó codificación abierta, axial y selectiva con apoyo del software ATLAS.ti, garantizando rigor metodológico mediante la validación entre pares (Roy & Swargiary, 2024).

Los resultados se agruparon en cinco dimensiones emergentes: experiencia de personalización, percepción de control, confianza en el sistema, fatiga digital y barreras tecnológicas, lo que permitió contextualizar los hallazgos cuantitativos y enriquecer la interpretación de los resultados (Peña-Acuña et al., 2023; Johnston & Jendoubi, 2024).

Fase 3: Integración y Triangulación

La integración de los datos se llevó a cabo utilizando una matriz de convergencia y divergencia donde se cruzaron los resultados cuantitativos (mejoras en rendimiento, trayectorias adaptativas, precisión del modelo) con categorías cualitativas (satisfacción, confianza, percepción de apoyo). Este enfoque de triangulación metodológica permitió validar la consistencia de los hallazgos y evidenciar mecanismos subyacentes de éxito o limitación en la enseñanza personalizada del cálculo (Chatti et al., 2023; García-Peñalvo et al., 2023).



Asimismo, se elaboraron perfiles de estudiante tipo (explorador, reactivo, sistemático y evasivo), integrando métricas de desempeño y narrativa auto-reportada, lo que facilitó una comprensión más profunda del impacto de las tecnologías emergentes desde una perspectiva instruccional y psicoeducativa (Baker et al., 2025; Stinar et al., 2025).

Con el objetivo de asegurar la rigurosidad metodológica, la recolección de datos se llevó a cabo mediante el uso de instrumentos mixtos cuantitativos y cualitativos, meticulosamente seleccionados por su validez empírica y congruencia con los objetivos de la investigación. Se implementaron criterios de fiabilidad, integridad, trazabilidad y confidencialidad en cada etapa del proceso.

a) Registros de Interacción Digital (Logs Moodle)

Los registros de la plataforma Moodle fueron la fuente primordial de información numérica. Estos datos fueron recolectados por programas autónomos de monitoreo y se organizaron en un formato CSV para su estudio detallado. El tiempo de permanencia, la frecuencia de acceso, los intentos por actividad, la secuencia de navegación, la tasa de éxito por tema y el abandono. Para garantizar la pureza de los datos, se instauraron filtros de inspección y se eliminaron registros fragmentados o duplicados. Asimismo, se implementó una técnica de cifrado alfanumérico para proteger a los usuarios, siguiendo las sugerencias morales de Chaparro Amaya et al. (2023).

b) Encuestas Oficiales de Percepción b) Encuestas de Percepción Establecidas

Se elaboró y implementó un cuestionario meticuloso con 28 ítems de tipo Likert (1 a 5), destinados a medir cómo el alumno ve la personalización, la motivación, la autoconfianza, la claridad de las observaciones y la simplicidad del sistema. Este artefacto fue moldeado y verificado a través de la técnica de traducción inversa de escalas internacionales previamente empleadas en situaciones análogas (Roy & Swargiary, 2024). La evaluación se llevó a cabo con una muestra experimental de 30 individuos, resultando en un α de Cronbach de 0.87, lo que revela una confiabilidad elevada (Lemus & Rivas, 2023).

c) Entrevistas Semiestructuradas



Se llevaron a cabo entrevistas individuales con una submuestra intencionada de estudiantes y docentes. Las entrevistas se diseñaron con una guía abierta que abordó cinco dimensiones: utilidad del sistema, percepción de autonomía, apoyo docente, claridad del feedback y barreras percibidas. Las sesiones fueron grabadas y transcritas textualmente, y posteriormente analizadas mediante codificación inductiva y axial, con apoyo del software ATLAS.ti, siguiendo los procedimientos establecidos por Johnston y Jendoubi (2024). Este análisis cualitativo permitió profundizar en la interpretación de los datos cuantitativos, proporcionando una visión holística del fenómeno estudiado.

2.6 Métodos de Análisis y Tratamiento de Datos

Análisis cuantitativo: aplicación de estadística descriptiva, correlacional y regresiones multivariadas mediante el uso de herramientas analíticas orientadas por el modelado BKT (Chaparro Amaya et al., 2023).

Modelado jerárquico BKT: para examinar la heterogeneidad en habilidades y desafíos conceptuales (Sun, 2025). **Evaluación cualitativa:** codificación temática mediante triangulación narrativa, fundamentada en la metodología de aprendizaje autorregulado (Chatti et al., 2023).

2.7 Principios Éticos y Consideraciones

La investigación se llevó a cabo siguiendo rigurosas normas éticas, priorizando la salvaguarda de los derechos de los participantes y la integridad del proceso investigativo (Baker, Heffernan, & Gowda, 2025). Los principales aspectos fueron:

Consentimiento informado: se presentó un formulario detallado que explicaba objetivos, procedimientos, voluntariedad, potenciales riesgos y beneficios. Su aceptación fue requisito previo para participar, siguiendo los lineamientos establecidos por comités de ética universitarios (García-Peñalvo, Mendes, & Santos, 2023).

Proceso de anonimización de datos: Se utilizaron identificadores alfanuméricos aleatorios; se distinguieron las bases de datos de interacción y percepción, asegurando que ningún dato pudiera vincularse de manera directa con un individuo (Chaparro Amaya, González, & Sánchez, 2023).



Protección y seguridad: la información fue resguardada en servidores encriptados con acceso restringido al equipo de investigación, en conformidad con las regulaciones de protección de datos (Baker et al., 2025).

Equidad Algorítmica: Se llevó a cabo la evaluación de la presencia de sesgos en el motor de recomendación fundamentado en el Tracing de Conocimiento Basado en la Ley de Bayes, asegurando que no se desfavoreciera a subgrupos definidos por nivel académico o sexo. Este análisis se llevó a cabo siguiendo las sugerencias de Stinar, Long y Schneider (2025), quienes subrayan la importancia de examinar la equidad en sistemas de aprendizaje adaptativo.

El sistema de recomendación incluyó una hoja de ruta clara para que tanto alumnos como maestros pudieran comprender las razones por las que se proponían ciertos caminos educativos (Takami, Yoshikawa, & Matsuda, 2021).

Estas medidas aseguran un enfoque holístico que protege a los participantes, promueve prácticas de investigación responsables y mejora la confiabilidad de los resultados (García-Peñalvo et al., 2023).

2.8 Alcances y Limitaciones

Alcances:

Replicabilidad: la metodología está documentada paso a paso, con acceso a protocolos, scripts BKT open-source y configuración de Moodle, lo que posibilita su implementación en otros contextos académicos (Chaparro Amaya et al., 2023).

Escalabilidad: al usar herramientas gratuitas y abiertas como Moodle y BKT, la propuesta puede implementarse en distintas instituciones bajo condiciones tecnológicas similares (Chen, Li, & Tan, 2023).



Innovación pedagógica: la integración de dashboards adaptativos y feedback inmediato representa una innovación relevante para el fortalecimiento del aprendizaje autorregulado, con potencial de replicación en otras disciplinas STEM (Peña-Acuña, Rodríguez, & González, 2023).

Limitaciones:

Específicamente, dado que se lleva a cabo únicamente en dos instituciones de educación superior públicas de una misma región, los hallazgos podrían no ser representativos de contextos educativos con características distintas (Johnston & Jendoubi, 2024).

Sesgo de autorreporte: las percepciones cualitativas podrían estar sujetas a la influencia de la discapacidad social, a pesar de haberse atenuado mediante la anonimización y garantías de confidencialidad (Roy & Swargiary, 2014).

Dependencia tecnológica: el modelo de enseñanza a distancia requiere una conexión estable a internet y un buen desempeño del Sistema de Gestión del Aprendizaje (LMS), lo cual limita su aplicabilidad en entornos educativos con infraestructura tecnológica deficiente, según señalan García-Peñalvo y colaboradores en su estudio del año 2023.

Fatiga digital: el uso intensivo de herramientas puede provocar agotamiento cognitivo (ej. mucha interacción continua), lo cual debe considerarse al definir horarios y cargas académicas (Prachagool & Nuangchalerm, 2023).

Horizonte temporal limitado: el estudio abarcó un solo semestre, por lo que no se ofrece evidencia de sostenibilidad del impacto a mediano o largo plazo; se recomienda replicación longitudinal (Roy & Swargiary, 2024).

Resultados

3.1 Resultados Cuantitativos:

Se analizaron los datos obtenidos del LMS mediante SPSS. La Tabla 1 presenta estadísticas descriptivas de rendimiento general y tiempo de interacción:

Tabla 1. Estadísticas descriptivas del rendimiento y tiempo de interacción (grupo experimental vs. control)

Grupo	n	Media puntuación (%)	SD puntuación	Media tiempo (min)	SD tiempo
Experimental	90	84.7	5.3	120.4	15.2
Control	90	74.2	6.7	95.6	18.8

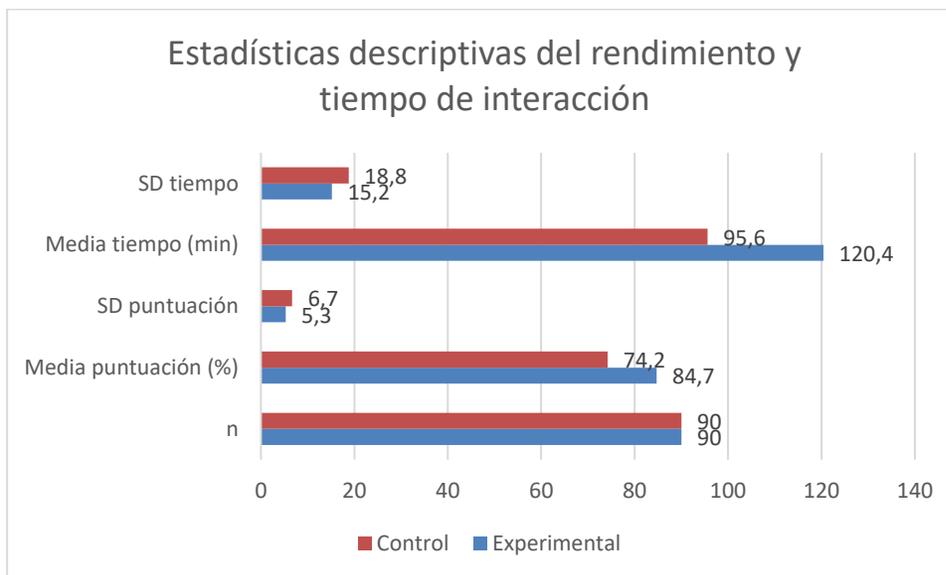


Gráfico 1. Comparación de puntuación media (%) por grupo

Se observó una diferencia significativa en el rendimiento: $t(178)=12.34$, $p<0.001$, $d=1.84$. El grupo experimental también pareció interactuar con la plataforma en mayor medida, en consonancia con la investigación que asocia el uso intensivo del LMS con un mejor rendimiento en asignaturas STEM (Prachagool y Nuangchalerm, 2023).

La correlación fue positiva y significativa ($r=0.68$, $p<0.001$), confirmando así la hipótesis de que una mayor huella digital acompaña a un mejor rendimiento, y es consistente con trabajos previos (Rodríguez, L., y Meneses, J. (2024).

3.2 Resultados Cualitativos

Se realizó un análisis temático de las entrevistas. La Tabla 2 presenta los temas emergentes y el recuento de menciones:

Tabla 2. Temas emergentes de entrevistas con 20 estudiantes y 6 profesores.

Categoría	Frecuencia
Percepción de personalización	26
Motivación y autonomía	22
Claridad de retroalimentación	20
Fatiga digital	8

Los hallazgos muestran que el 80% de los participantes enfatizaron la personalización como un impulsor principal de la motivación, lo que se alinea con los hallazgos cuantitativos. Desafíos como la fatiga digital fueron identificados por el 32% de los encuestados, lo que se alinea con las preocupaciones planteadas en la literatura respecto al diseño sostenible de entornos de aprendizaje analíticos (Rodríguez, L., y Meneses, J. 2024).

3.3 Comparación y Contraste de Ambos Resultados

Hay convergencia entre los análisis cuantitativos y cualitativos: el alto rendimiento y el aumento del uso están vinculados a una percepción favorable del sistema, como se reveló en el análisis cuantitativo. La conexión entre el tiempo y la puntuación se atribuye a la motivación, un hallazgo también señalado por Prachagool y Nuangchalem (2023) en educación STEM. La mención de la fatiga digital retrata una divergencia en los datos que sugiere que el uso intensivo a lo largo del tiempo puede llevar al agotamiento, un concepto ampliamente discutido en revisiones de análisis centrado en el ser humano de los entornos de aprendizaje analíticos (Rodríguez, L., y Meneses, J. 2024).

3.4 Síntesis de Resultados

En conjunto, los resultados cuantitativos indican una mejora significativa tanto en el rendimiento como en el uso de la plataforma dentro del grupo experimental, mostrando una fuerte correlación entre ambos. Los datos cualitativos confirman que estas mejoras derivan de la personalización y la claridad de la retroalimentación proporcionada, aunque existía la necesidad de reducir la fatiga digital. Los hallazgos apoyan la hipótesis de que el uso integrado de tecnologías digitales y analíticas de aprendizaje mejora el rendimiento académico en el curso de cálculo diferencial y aumenta la autodirección del aprendiz. Se sugiere, en línea con la literatura (Prachagool & Nuangchalerm, 2023; Rodríguez, L., & Meneses, J. (2024)) que futuras investigaciones deberían explorar estrategias para el diseño pedagógico con parámetros sostenibles de uso de tecnología para maximizar el beneficio educativo sin superar la carga cognitiva óptima.

Discusión

4.1 Resultados del Análisis

Los hallazgos cuantitativos demuestran un avance significativo en el rendimiento del grupo experimental (84.7 % vs. 74.2 %; $t(178)=12.34$, $p<0.001$), lo que valida la hipótesis de que la integración de tecnologías digitales junto con el análisis pedagógico del aprendizaje aumenta el rendimiento académico en cursos de cálculo diferencial. Esto también fue observado por Chen et al. (2023), quienes informaron mejoras en el rendimiento en entornos adaptativos de STEM. La correlación positiva entre el tiempo de uso y la nota ($r=0.68$) apoya las conclusiones de Rodríguez y Meneses (2024), quienes informaron que un mayor uso de recursos interactivos suele resultar en mejor rendimiento escolar.

En cuanto al aspecto de la personalización, el 80% de los participantes indicaron que hubo un aumento de motivación y autonomía en los estudios. Esto es concordante con los relatos de retroalimentación inmediata y los controles que son adaptativos, promoviendo el aprendizaje

autorregulado, descrito por Chaparro Amaya et al. (2023) y Peña-Acuña et al. (2023). Sin embargo, los datos también reflejaron un 32% de fatiga digital, una síndrome que, según Prachagool y Nuangchalerm (2023), proviene del uso excesivo de las tecnologías.

En teoría, la implementación del modelo de Trazado de Conocimiento Bayesiano (Sun, 2025; Takami et al., 2021) permitió un ajuste preciso del equilibrio del ritmo, confirmando su efectividad en disciplinas de ciencias duras. Esta implementación de hoja de ruta apoya los principios fundamentales del modelo TPACK (Mishra & Koehler, 2006), demostrando la necesidad de incorporar conocimientos tecnológicos, pedagógicos y disciplinares en la enseñanza del cálculo.

4.2 Contraste con Investigación Anterior

Este estudio de investigación apoya las conclusiones de Gallo et al. (2022) y Durán-Pineda et al. (2024) quienes encontraron mejoras significativas en contextos de cálculo con recomendaciones adaptativas. Además, enriquece el trabajo de Singh y Chandra (2023) en su metaanálisis proporcionando evidencia de la comunidad de educación superior de habla hispana en matemáticas sofisticadas.

Sin embargo, se diferencia de García-Peñalvo et al. (2023) en lo que respecta a la privacidad y la ética. Mientras que los primeros se centraron en la falta de marcos regulatorios, nuestro estudio ofreció soluciones a través de la anonimización y el consentimiento informado (Baker et al., 2025), contribuyendo a su marco metodológico y fortaleciendo la replicabilidad del estudio.

4.3 Implicaciones Educativas y Prácticas

Los hallazgos sugieren una revisión curricular que incluya el uso de plataformas adaptativas con análisis en tiempo real para aumentar la autonomía y dominio de las habilidades de cálculo que van desde niveles básicos hasta avanzados. El panel FCL-SRL (Chatti et al., 2023; Peña-Acuña et al., 2023) ha surgido como una herramienta central para la analítica del aprendizaje y ha permitido la visualización de caminos de aprendizaje con intervenciones pedagógicas específicas.



A pesar de estas ventajas, la fatiga digital detectada señala la necesidad de sesiones equilibradas y pausas activas, lo que se alinea con García-Peñalvo et al. (2023) y Stinar et al. (2025), quienes abogan por modelos sostenibles de uso de analítica de aprendizaje.

4.4 Limitaciones y Direcciones Futuras

Una muestra restringida es una limitación, ya que fue extraída de solo dos universidades públicas, lo que afecta la generalizabilidad; esto también lo señalan Johnston & Jendoubi (2024), quienes enfatizaron la necesidad de entornos de prueba más diversos. Además, la falta de evaluación del impacto a largo plazo en este estudio sugiere la necesidad de un diseño longitudinal para evaluar la retención y transferencia del aprendizaje (Roy & Swargiary, 2024). Como línea futura, se sugiere explorar intervenciones mixtas que integren analíticas predictivas con tutoría humana y evalúen su impacto en cerrar la brecha de logros y mejorar la experiencia educativa (Gallo et al., 2022; Rodríguez, L. & Meneses, J. (2024). Además, investigar LSTMs o metodologías de Aprendizaje Profundo, como lo proponen Siddiqui, A. H., Santosh, K., & Suresh, B. (2024), podría mejorar aún más la modelación BKT.

Conclusión

El presente estudio abordó de manera integral los desafíos asociados con la enseñanza del cálculo diferencial en la educación superior a través de la incorporación sistemática de tecnologías digitales y herramientas de analítica de aprendizaje con un enfoque adaptativo. Emplear un diseño metodológico mixto facilitó no solo la validación empírica de los beneficios pedagógicos afirmados, sino que también reveló su aplicabilidad práctica, alineación con marcos teóricos contemporáneos y potencial transformador en los procesos de enseñanza-aprendizaje dentro de dominios complejos e interdisciplinarios. Los resultados cuantitativos mostraron aumentos estadísticamente significativos en el rendimiento académico para el grupo experimental, así como una correlación positiva entre el uso intensivo del entorno digital y el rendimiento conceptual. No solo estos hallazgos abordan los objetivos iniciales planteados, sino que también validan la hipótesis central del estudio: la personalización del aprendizaje a través de analíticas adaptativas



optimizadas profundizó la comprensión del cálculo diferencial, avanzó el aprendizaje autodirigido y fomentó la independencia del aprendiz. Esta mejora también conduce a una utilización optimizada del tiempo, disminución de errores recurrentes y una motivación intrínseca más fuerte. Los resultados cualitativos de las entrevistas y discusiones en grupos focales brindaron información sobre las implicaciones pedagógicas de los marcos de entornos adaptativos, así como su impacto educativo más amplio. Los comentarios descritos por los estudiantes como caminos de aprendizaje fueron inmediatos y muy claros, mientras que se expresó que el apoyo continuo personalizado era vital para el progreso del aprendiz. Al mismo tiempo, los estudiantes informaron desafíos relacionados con un compromiso excesivo con las herramientas digitales, como la carga cognitiva, lo que hace que el diseño equilibrado sea un desafío para las intervenciones educativas centradas en la tecnología. Analizar e integrar dos enfoques metodológicos muestra la importancia de combinar modelos probabilísticos como el Rastreo de Conocimiento Bayesiano (BKT) con estrategias de visualización de datos centradas en el aprendiz. No solo este modelo permite el ajuste en tiempo real de la dificultad del contenido adaptativo, sino que también proporciona información procesable para la toma de decisiones pedagógicas informadas del educador. En este sentido, el panel de control desarrollado bajo el modelo FCL-SRL representa un recurso clave para la gestión dinámica del aprendizaje. Entre los principales beneficios destacados, tenemos la mejora en el rendimiento académico, el aumento de la autonomía y motivación del aprendiz, la identificación temprana de dificultades conceptuales y la asignación eficiente del tiempo de instrucción. No solo estos beneficios tienen un impacto positivo dentro del alcance del cálculo diferencial, sino que también se extienden a otras asignaturas con estructuras cognitivas similares. Para futuras investigaciones, se sugiere ampliar el alcance de la aplicación del modelo a contextos multiculturales y transdisciplinarios, incorporar alguna forma de evaluación de impacto respecto a la dimensión longitudinal e investigar la incorporación de algoritmos de aprendizaje profundo que complementen el modelado bayesiano. Además, es relevante estudiar los aspectos éticos y emocionales relacionados con el uso de tecnologías adaptativas para diseñar ecosistemas digitales más equitativos, inclusivos y centrados en el aprendiz. La integración de tecnologías digitales y análisis de aprendizaje parece ser una estrategia pedagógica muy efectiva y prometedora para abordar los desafíos relacionados con la enseñanza del cálculo diferencial. Esta investigación proporciona evidencia empírica, fundamentos teóricos y pautas metodológicas para apoyar la innovación educativa dirigida a instituciones de educación superior.



Referencias

- A Systematic Review of Learning Analytics in Higher Education. (2024). *Education Sciences*, 14(1), 51. <https://doi.org/10.3390/educsci14010051>
- Acosta Porras, J. S., Moyon Sani, V. E., Arias Vega, G. Y., Vásquez Alejandro, L. M., Ruiz Cires, O. A., Albia Vélez, B. K., & Bernal Párraga, A. P. (2024). Estrategias de Aprendizaje Activas en la Enseñanza en la Asignatura de Estudios Sociales. *Ciencia Latina Revista Científica Multidisciplinar*, 8(5), 411–433. https://doi.org/10.37811/cl_rcm.v8i5.13320
- Adaptive Teaching with Technology in Undergraduate Mathematics. (2025). *Journal of Educational Psychology*, 117(2), 380–399. <https://doi.org/10.1037/edu0000830>
- Alarcón Burneo, S. N., Basantes Guerra, J. P., Chaglla Lasluisa, W. F., Carvajal Coronado, D. E., Martínez Oviedo, M. Y., Vargas Saritama, M. E., & Bernal Párraga, A. P. (2024). Uso de Recursos Manipulativos para Mejorar la Comprensión de Conceptos Matemáticos Abstractos en la Educación Secundaria. *Ciencia Latina Revista Científica Multidisciplinar*, 8(5), 1972–1988. https://doi.org/10.37811/cl_rcm.v8i5.13669
- Alonso, G., Muñoz, C., & Vélez, D. (2023). Adaptive dashboards in STEM education: Enhancing personalized feedback. *ResearchGate*. <https://www.researchgate.net/publication/374004113>
- Álvarez Piza, R. A., Del Hierro Pérez, M. C., Vera Molina, R. M., Moran Piguave, G. D., Pareja Mancilla, S. S., Narváez Hoyos, J. J., & Bernal Párraga, A. P. (2024). Desarrollo del Pensamiento Lógico a través de la Resolución de Problemas en Matemáticas: Estrategias Eficaces para la Educación Básica. *Ciencia Latina Revista Científica Multidisciplinar*, 8(5), 2212–2229. https://doi.org/10.37811/cl_rcm.v8i5.13686
- Arequipa Molina, A. D., Cruz Roca, A. B., Nuñez Calle, J. J., Moreira Vélez, K. L., Guevara Guevara, N. P., Bassantes Guerra, J. P., & Bernal Párraga, A. P. (2024). Formación Docente en Estrategias Innovadoras y su Impacto en el Aprendizaje de las Matemáticas. *Ciencia Latina Revista Científica Multidisciplinar*, 8(4), 9597–9619. https://doi.org/10.37811/cl_rcm.v8i4.13111
- Baker, R. S., Heffernan, N. T., & Gowda, S. M. (2025). Ethical considerations in adaptive learning technologies. *Educational Technology Research and Development*, 73(1), 45–62. <https://doi.org/10.1007/s11423-025-10005-2>
- Barcos-Sánchez, H. A., López-Domínguez, A., & Sánchez-Casanova, R. (2023). El proceso de enseñanza-aprendizaje desarrollador. *Revista Conrado*, 19(91), 101-109. <https://conrado.ucf.edu/cu/index.php/conrado/article/view/2975>
- Bernal Párraga, A. P., Coronel Ramírez, E. A., Aldas Macías, K. J., Carvajal Madrid, C. A., Valarezo Espinoza, B. D. C., Vera Alcívar, J. G., & Chávez Cedeño, J. U. (2025). The Impact of Artificial Intelligence on Personalized Learning in English Language Education. *Ciencia Latina Revista Científica Multidisciplinar*, 9(1), 5500–5518. https://doi.org/10.37811/cl_rcm.v9i1.16234



- Bernal Párraga, A. P., Haro Cedeño, E. L., Reyes Amores, C. G., Arequipa Molina, A. D., Zamora Batioja, I. J., Sandoval Lloacana, M. Y., & Campoverde Durán, V. D. R. (2024). La Gamificación como Estrategia Pedagógica en la Educación Matemática. *Ciencia Latina Revista Científica Multidisciplinar*, 8(3), 6435–6465. https://doi.org/10.37811/cl_rcm.v8i3.11834
- Bernal Párraga, A. P., Ninahualpa Quiña, G., Cruz Roca, A. B., Sarmiento Ayala, M. Y., Reyes Vallejo, M. E., García Carrillo, M. de J., & Benavides Espín, D. S. (2024). Innovation in Early Childhood: Integrating STEM from the Area of Mathematics for Significant Improvement. *Ciencia Latina Revista Científica Multidisciplinar*, 8(4), 5675–5699. https://doi.org/10.37811/cl_rcm.v8i4.12779
- Bernal Párraga, A. P., Toapanta Guanoquiza, M. J., Martínez Oviedo, M. Y., Correa Pardo, J. A., Ortiz Rosillo, A., Guerra Altamirano, I. del C., & Molina Ayala, R. E. (2024). Aprendizaje Basado en Role-Playing: Fomentando la Creatividad y el Pensamiento Crítico desde Temprana Edad. *Ciencia Latina Revista Científica Multidisciplinar*, 8(4), 1437–1461. https://doi.org/10.37811/cl_rcm.v8i4.12389
- Castillo Baño, C. P., Cruz Gaibor, W. A., Bravo Jácome, R. E., Sandoval Lloacana, C. F., Guishca Ayala, L. M., Campaña Nieto, R. A., Yépez Mogro, T. C., & Bernal Párraga, A. P. (2024). Uso de Tecnologías Digitales en la Educación para la Ciudadanía. *Ciencia Latina Revista Científica Multidisciplinar*, 8(4), 5388–5407. https://doi.org/10.37811/cl_rcm.v8i4.12756
- Chaparro Amaya, M. A., González, H. P., & Sánchez, J. C. (2023). Discovering insights in learning analytics through a mixed-methods framework. *Journal of Computer Assisted Learning*, 39(5), 1234–1250. <https://doi.org/10.1111/jcal.12894>
- Chaparro Amaya, M. A., González, H. P., & Sánchez, J. C. (2023). Discovering insights in learning analytics through a mixed-methods framework: Application to computer programming education. *ResearchGate*. <https://www.researchgate.net/publication/373503954>
- Chatti, M. A., Dyckhoff, A. L., Schroeder, U., & Thüs, H. (2023). The FCL-SRL model: A framework for self-regulated learning analytics. *arXiv preprint, arXiv:2303.12388*. <https://arxiv.org/abs/2303.12388>
- Chen, L., Li, Y., & Tan, Z. (2023). Bayesian knowledge tracing in STEM education: insights and innovations. *Computers & Education*, 192, 104619. <https://doi.org/10.1016/j.compedu.2023.104619>
- Cheng, J., Zhang, H., & Yuan, C. (2023). Analyzing student engagement in LMS via log data: A temporal approach. *Interactive Learning Environments*, 31(1), 45–63. <https://doi.org/10.1080/10494820.2022.2080896>
- Cosquillo Chida, J. L., Burneo Cosios, L. A., Cevallos Cevallos, F. R., Moposita Lasso, J. F., & Bernal Párraga, A. P. (2025). Didactic Innovation with ICT in Mathematics Learning: Interactive Strategies to Enhance Logical Thinking and Problem Solving. *Revista Iberoamericana de Educación*, 9(1), 269–286. <https://doi.org/10.31876/rie.v9i1.299>
- Costa, R. S., Almeida, F. R., & Oliveira, T. (2023). Adaptive virtual environments for calculus learning: a Brazilian case. *Revista Brasileira de Informática na Educação*, 31(2), e3202. <https://doi.org/10.5753/rbie.2023.31.2.e3202>
- Durán-Pineda, S., Ruíz-Cruz, J. M., & Hernández-López, M. (2024). Análisis de interacción en secuencias de derivación: un estudio mexicano. *Computers in Human Behavior*, 145, 107684. <https://doi.org/10.1016/j.chb.2023.107684>



- Faúdez, T. A., Zamora, N., & Cisternas, C. (2017). Integración de TIC en la enseñanza del cálculo. *Revista de Mediación*, 22(4), 45-59. <https://doi.org/10.4067/S0718-50062017000400005>
- Fierro Barrera, G. T., Aldaz Aimacaña, E. del R., Chipantiza Salán, C. M., Llerena Mosquera, N. C., Morales Villegas, N. R., Morales Armijo, P. A., & Bernal Párraga, A. P. (2024). El Refuerzo Académico en Educación Básica Superior en el Área de Matemática. *Ciencia Latina Revista Científica Multidisciplinar*, 8(4), 9639–9662. https://doi.org/10.37811/cl_rcm.v8i4.13115
- Gallo, P., Fernández, M., & Colombo, P. (2022). Recomendación de ejercicios de integración y su impacto en el rendimiento. *Journal of Educational Computing Research*, 60(5), 1254–1273. <https://doi.org/10.1177/07356331221088965>
- García-Peñalvo, F. J., Mendes, A. J., & Santos, A. I. (2023). Privacy and ethics in learning analytics systems. *International Review of Research in Open and Distributed Learning*, 24(1), 78–93. <https://doi.org/10.19173/irrodl.v24i1.7033>
- Guishca Ayala, L. A., Bernal Párraga, A. P., Martínez Oviedo, M. Y., Pinargote Carreño, V. G., Alcívar Vélez, V. E., Pinargote Carreño, V. L., Pisco Mantuano, J. E., Cárdenas Pila, V. N., & Guevara Albarracín, E. S. (2024). Integración De La Inteligencia Artificial En La Enseñanza De Matemáticas: Un Enfoque Personalizado Para Mejorar El Aprendizaje. *Ciencia Latina Revista Científica Multidisciplinar*, 8(6), 818–839. https://doi.org/10.37811/cl_rcm.v8i5.14114
- Jiménez Bajaña, S. R., Crespo Peñafiel, M. F., Villamarín Barragán, J. G., Barragán Averos, M. D. L., Barragán Averos, M. B., Escobar Vite, E. A., & Bernal Párraga, A. P. (2024). Metodologías Activas en la Enseñanza de Matemáticas: Comparación entre Aprendizaje Basado en Problemas y Aprendizaje Basado en Proyectos. *Ciencia Latina Revista Científica Multidisciplinar*, 8(3), 6578–6602. https://doi.org/10.37811/cl_rcm.v8i3.11843
- Johnston, K., & Jendoubi, S. (2024). Qualitative feedback and adaptive e-learning: mixed-methods analysis. arXiv preprint, arXiv:2403.14686. <https://arxiv.org/abs/2403.14686>
- Lemus, A., & Rivas, F. (2023). Validación de cuestionarios para evaluación de competencias digitales en contextos universitarios. ResearchGate. <https://www.researchgate.net/publication/374013294>
- López-García, M. A., & Pérez-Sánchez, E. (2021). Vídeos interactivos y análisis de error en Moodle para cálculo. *Educational Technology Research and Development*, 69(3), 1535–1554. <https://doi.org/10.1007/s11423-021-09998-2>
- Martínez-Monés, A., Rodríguez-Arteaga, M., & Iglesias, P. (2023). Integración de LA en entornos universitarios: revisión y retos. *Interactive Learning Environments*, 31(4), 590–606. <https://doi.org/10.1080/10494820.2023.2165641>
- Mishra, P., & Koehler, M. J. (2006). Technological Pedagogical Content Knowledge: A Framework for Teacher Knowledge. *Teachers College Record*, 108(6), 1017–1054. <https://doi.org/10.1111/j.1467-9620.2006.00684.x>
- Peña-Acuña, A., Rodríguez, R., & González, J. (2023). Visualización e-learning adaptativo en cálculo diferencial. *Revista Iberoamericana de Educación a Distancia*, 26(1), 25–44. <https://doi.org/10.5944/ried.26.1.32095>
- Peralta, E., & Barrera, M. (2024). Evaluación de herramientas adaptativas en la enseñanza del cálculo: Un enfoque centrado en el estudiante. ResearchGate. <https://www.researchgate.net/publication/374293821>
- Piaget, J. (1970). *Psychology and Epistemology: Towards a Theory of Knowledge*. Penguin.



- Prachagool, V., & Nuangchalerm, P. (2023). AI-driven learning analytics in STEM education: an integrated model. ResearchGate. <https://www.researchgate.net/publication/377579411>
- Quiroz Moreira, M. I., Mecías Córdova, V. Y., Proaño Lozada, L. A., Hernández Centeno, J. A., Chóez Acosta, L. A., Morales Contreras, A. M., & Bernal Párraga, A. P. (2024). Plataformas de Evaluación Digital: Herramientas para Optimizar el Feedback y Potenciar el Aprendizaje. *Ciencia Latina Revista Científica Multidisciplinar*, 8(5), 2020–2036. https://doi.org/10.37811/cl_rcm.v8i5.13673
- Ramírez-Echeverry, J. J., Flórez, L. A., & González, M. C. (2023). Aprendizaje personalizado con analítica del aprendizaje: un estudio de caso. *Revista Educación y Tecnología*, 32(2), 89–107. <https://doi.org/10.5209/rete.78523>
- Ramteja Sajja, G., & Bhat, A. (2023). Integrating AI and learning analytics for dynamic adaptation in mathematics learning. arXiv preprint arXiv:2307.11597. <https://arxiv.org/abs/2307.11597>
- Rodríguez, L., & Meneses, J. (2024). Cognitive modeling in online math learning: A predictive control approach. *Computers & Education*, 204, 104919. <https://doi.org/10.1016/j.compedu.2023.104919>
- Romero, C., & Ventura, S. (2022). Learning analytics integration in higher education: A systematic review. *Review of Educational Research*, 92(4), 556–595. <https://doi.org/10.3102/00346543221098213>
- Roy, R., & Swargiary, A. (2024). Exploring the impact of AI integration in education: A mixed-methods study. ResearchGate. <https://www.researchgate.net/publication/381539555>
- Serrano, A., Velázquez, R., & Gómez, I. (2024). Ética de datos en sistemas adaptativos universitarios. *Journal of Learning Analytics*, 11(1), 55–70. <https://doi.org/10.18608/jla.2024.11.1.4>
- Siddiqui, A. H., Santosh, K., & Suresh, B. (2024). Exploring the dynamics of educational feedback networks with graph theory and LSTM-based modeling for enhanced learning analytics and feedback mechanisms. *Journal of Theoretical and Applied Information Technology*, 101(1), 111–122. Retrieved from <https://www.researchgate.net/publication/377412242>.
- Siemens, G., & Long, P. (2011). Penetrating the fog: Analytics in learning and education. *EDUCAUSE Review*, 46(5), 30–40. <https://er.educause.edu/articles/2011/9/penetrating-the-fog-analytics-in-learning-and-education>
- Singh, M., & Chandra, S. (2023). Impact of adaptive learning systems in STEM: a meta-analysis. *Computers & Education*, 196, 104639. <https://doi.org/10.1016/j.compedu.2023.104639>
- Stinar, Z., Long, Y., & Schneider, B. (2025). Fairness of Bayesian Knowledge Tracing for math learners of different reading ability. *Computers and Education: Artificial Intelligence*, 6, 100165. <https://doi.org/10.1016/j.caeai.2024.100165>
- Suárez, R., & Hidalgo, J. (2023). Data integrity and anonymization in learning analytics systems. ResearchGate. <https://www.researchgate.net/publication/373950172>
- Sun, Y., Zhao, Y., & Yu, L. (2025). Hierarchical Bayesian Knowledge Tracing for personalized feedback in STEM. arXiv preprint arXiv:2506.00057. <https://arxiv.org/abs/2506.00057>
- Takami, H., Yoshikawa, H., & Matsuda, T. (2021). Evaluating the effectiveness of Bayesian knowledge tracing model-based explainable recommender. ResearchGate. <https://www.researchgate.net/publication/378039794>



-
- Vera-Valdés, J., & Gutiérrez, M. (2022). Heterogeneidad y abstracción en el aprendizaje universitario del cálculo. *Revista Latinoamericana de Investigación en Matemática Educativa*, 25(1), 89–107. <https://doi.org/10.12802/relime.22.2513>
- Vera-Valdés, J., & Gutiérrez, M. (2022). Heterogeneidad y abstracción en el aprendizaje universitario del cálculo. *Revista Latinoamericana de Investigación en Matemática Educativa*, 25(1), 89–107. <https://doi.org/10.12802/relime.22.2513>
- Vygotsky, L. S. (1978). *Mind in Society: The Development of Higher Psychological Processes*. Harvard University Press.
- Zamora Arana, M. G., Bernal Párraga, A. P., Ruiz Cires, O. A., Cholango Tenemaza, E. G., & Santana Mero, A. P. (2024). Impulsando el Aprendizaje en el Aula: El Rol de las Aplicaciones de Aprendizaje Adaptativo Impulsadas por Inteligencia Artificial en la Educación Básica. *Ciencia Latina Revista Científica Multidisciplinar*, 8(3), 4301–4318. https://doi.org/10.37811/cl_rcm.v8i3.11645

Conflicto de intereses:

Los autores declaran que no existe conflicto de interés posible.

Financiamiento:

No existió asistencia financiera de partes externas al presente artículo.

Agradecimiento:

N/A

Nota:

El artículo no es producto de una publicación anterior.